

基于深度学习的永磁同步电机故障诊断方法

张周磊¹ 李垣江^{1,2} 李梦含¹ 魏海峰^{1,2}

¹(江苏科技大学电子信息学院 江苏 镇江 212003)

²(常熟瑞特电气股份有限公司 江苏 常熟 215500)

摘要 针对永磁同步电机匝间短路和永磁体失磁故障因处理复杂、特征独立单一和样本稀少等因素引起的诊断偏差问题,提出一种基于深度学习变分自编码网络的故障特征样本快速扩展策略及融合稀疏自编码网络的故障诊断方法。通过组合永磁同步电机频域电流、磁通密度、电磁转矩特征,结合变分自编码网络的生成模型实现故障真实样本扩张,构建丰富、多样、更具鲁棒性的训练集合。将优化数据集输入稀疏自编码网络训练诊断模型,用测试数据验证网络的优劣。实验结果表明,相比传统故障诊断方法,该算法能更加高效快速地实现匝间短路及失磁故障诊断。

关键词 匝间短路 电机失磁 变分自编码网络 稀疏自编码网络 特征扩张 故障诊断

中图分类号 TP277 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2019.10.022

FAULT DIAGNOSIS METHOD OF PERMANENT MAGNET SYNCHRONOUS MOTOR BASED ON DEPTH LEARNING

Zhang Zhoulei¹ Li Yuanjiang^{1,2} Li Menghan¹ Wei Haifeng^{1,2}

¹(School of Electronic Information, Jiangsu University of Science and Technology, Zhenjiang 212003, Jiangsu, China)

²(Changshu Rhett Electric Co., Ltd., Changshu 215500, Jiangsu, China)

Abstract Aiming at the problem of diagnostic deviation caused by complex processing, independent single feature and few samples of interturn short circuit and permanent magnet loss of excitation faults of permanent magnet synchronous motor, this paper proposed a fast expansion strategy of fault feature samples based on deep learning variational auto-encoder network and a fault diagnosis method combining sparse auto-encoder network. By combining the characteristics of frequency domain current, flux density and electromagnetic torque of permanent magnet synchronous motor, and combining with the generation model of variational auto-encoder network, the real fault samples were expanded, and we constructed a rich, diverse and more robust training set. The optimized data set was input into the sparse auto-encoder network training diagnosis model, and the test data were used to verify the network's advantages and disadvantages. The experimental results show that compared with traditional fault diagnosis methods, our method can achieve interturn short circuit and loss of excitation fault diagnosis more efficiently and quickly.

Keywords Interturn short circuit Motor excitation-loss Variational self-coding network Sparse self-coding network Characteristic expansion Fault diagnosis

0 引言

匝间短路及永磁体的失磁是典型的、破坏性极强

的永磁同步电机(PMSM)故障。若轻微的匝间短路故障未加以关注,则短路环流持续上升产生高温引起退磁现象,最终导致电机无法运行,甚至烧毁电机。因此,匝间短路和失磁故障特征的研究以及特征数据集

收稿日期:2019-02-24。国家自然科学基金项目(61503161,61771225);江苏省重点研发计划(社会发展)项目(BE2016723);江苏省研究生科研与实践创新计划项目(KYCX18_2328);江苏省产学研前瞻性联合研究项目(BY2016073-01)。张周磊,硕士,主研领域:人工智能应用,深度学习,故障诊断。李垣江,副教授。李梦含,硕士。魏海峰,副教授。

的优化对于高效、准确、低耗、省时地进行故障检测具有重要的意义。

现阶段,永磁同步电机匝间短路及永磁体失磁故障的研究大多通过信号变换方法,将电机信号(输出电流、反向电动势等)精确分解成重要信息块,并作为诊断故障的标准。常用的方法包括:小波变换(WT)^[1]、傅里叶变换(FFT)^[2]、经验模态分解(EMD)^[3]等。定子电流谐波频谱分析^[4]对于电机故障具有强相关性,因此对谐波的FFT频域分析是目前研究较多的方法。该方法能够有效诊断电机状态,但是受环境因素的影响(转速、温度),谐波次数会不尽相同,所需表达的电机模型也会相对复杂。而电机参数辨识方法^[5]通过识别各状态参数(负序特征、振动、转矩等)判断其运行状态,确认故障类型及劣化程度。该方法可以简化操作过程,但由于各参数之间是相互独立的,在分析多故障状态时,已有的参数未能完整表示电机故障,因此诊断效率并不高。

深度神经网络在图像识别、数据挖掘领域取得了显著成就。基于深度学习参数特征的数据挖掘可以大大提高电机故障诊断的准确性。文献[6]基于定轴变速齿轮特征,在100组有限样本数量条件下,利用粒子支持向量机实现齿轮智能故障诊断,效率能够达到95%以上。文献[7]基于振动信号特征,在400个有限样本数量条件下,采用去噪稀疏自编码网络实现异步电机6类故障诊断,结果达到97%以上。然而多故障电机模型组件内部存在强相关联,导致电机故障具有一定的随机性、并发性。因此小样本深度学习网络特征提取对于结果意义较小,海量且有效的参数样本数据是提升深度学习故障诊断准确率的关键。

本文结合信号处理(定子谐波电流)与参数识别(电磁转矩、磁感应强度)方法,分析特征与故障的关联性,建立特征组合样本,从而改善效率低下的问题。通过变分自编码网络^[8](Variational Auto-Encoder Net, VAE)对数据样本进行特征提取并将其作用于生成模块进行伪样本扩展,最终生成的样本能够高拟合原样本数据,解决故障诊断深度网络训练数据集稀缺的问题,大大节约资源和时间。最后利用稀疏自编码网络(Sparse Auto-Encoder Net, SAE)学习优化后的数据集特征,将训练好的网络作为永磁同步电机故障诊断的标准。

1 深度学习故障诊断网络模型

1.1 变分自编码网络

神经网络故障诊断主要以监督学习为主,因此海

量的标签数据是高效网络诊断的关键。而人工生成标注样本数据存在工作量大、消耗资源多、周期长等缺点,为了解决此类问题,本文利用深度生成变分自编码网络无监督学习已知样本,并基于学到的数据概率分布生成伪样本。

标准自编码网络目标仅仅是数据降维、特征提取,而变分自编码网络的区别之处在于能够训练出潜变量 Z 的概率分布,通过 Z 分布采样生成新样本。如图1所示。




图1 变分自编码

已知故障样本数据 X 通过 $p(Z|X)$ 推断出 Z :

$$p(Z|X) = \frac{p(X|Z)p(Z)}{p(X)} \quad (1)$$

$$p(X) = \int p(X|Z)p(Z)dZ \quad (2)$$

由于 X 为高维的连续变量, $p(X)$ 处于复杂的分布,所以通过概率论方法很难计算 Z 。因此应用变分推断(Variational inference)方法利用分布 $q(Z)$ 近似 $p(Z|X)$,通过KL散度^[9]衡量两者近似程度。

$$KL(q(Z) \parallel p(Z|X)) = \int q(Z) \log \frac{q(Z)}{p(Z|X)} dZ = \int q(Z) [\log q(Z) - \log p(Z|X)] dZ \quad (3)$$

将式(3)进行贝叶斯公式变换得到:

$$\log p(X) - KL(q(Z) \parallel p(Z|X)) = \int q(Z) \log p(X|Z) dZ - KL(q(Z) \parallel p(Z)) \quad (4)$$

故障样本 X 已知情况下 $p(X)$ 为固定值,因此为了缩短 $q(Z)$ 与 $p(Z|X)$ 之间的距离,需要对式(4)等号右侧进行处理:

(1) Decoder:等号右侧第一项的 \log 似然期望最大化;

(2) Encoder:等号右侧第二项 $q(Z)$ 与 $p(Z)$ KL散度最小化。

另一方面可以将随机变量 Z 分为两个部分:确定部分 X ;随机部分 ε 。条件概率 $z = g_\phi(X, \varepsilon)$, g_ϕ 为组合函数。 ε 决定了 z 条件概率值的变化趋势,则 $q(Z) = p(\varepsilon)$,处理式(4)得:

$$\log p(X) - KL(q(X) \parallel p(Z|X)) = \int p(\varepsilon) \log p(X|g_\phi(X, \varepsilon)) d\varepsilon - KL(p(\varepsilon) \parallel p(Z)) \quad (5)$$

式(5)中: $KL(p(\varepsilon) \parallel p(Z))$ 是变分自编码网络的编码

阶段,通过获取近似的变分推断函数 $q(Z)$ 计算样本 X 的潜变量 Z 。 $\int p(\varepsilon) \log p(X|g_\phi(X, \varepsilon)) d\varepsilon$ 是解码阶段,最大化 $p(X|Z)$ 概率从而采样 Z 生成伪样本 \hat{X} 。

变分自编码网络可以划分为编码器和解码器。为了简化网络求解过程,假设 $q(Z)$ 服从多维高斯分布^[10], $p(Z)$ 服从标准正态分布,则编码阶段 $q(Z)$ 与 $p(Z)$ 的 KL 散度即可表示为:

$$KL(p(\varepsilon) \parallel N(0,1)) = \frac{1}{2}[-\log\det(\Sigma_\varepsilon) - d + \text{tr}(\Sigma_\varepsilon) + \mu_\varepsilon^T \mu_\varepsilon] \quad (6)$$

式中: d 为隐变量的维度; Σ_ε 为方差矩阵。

将高斯分布分解为均值与方差形式:

$$KL(N(\mu, \sigma^2) \parallel N(0,1)) = \frac{1}{2}(-\log\sigma^2 + \mu^2 + \sigma^2 - 1) \quad (7)$$

从式(7)可以很清晰地看出 KL 散度与 (μ, σ) 的关系,通过不断优化均值及方差参数使散度距离最小化实现 $p(Z|X)$ 目标的近似。Encoder 网络模型如图 2 所示。




图 2 VAE 网络 Encoder 模型

将上述由均值及方差组成的潜变量 Z 作为解码阶段(Decoder)的采样输入,这样的采样过程会遇到困难: $Z \sim N(\mu, \sigma^2)$ 参加采样操作时均值和方差不可导从而导致网络梯度下降训练不可实行。为解决难题,引用重参数方法^[11]来实现误差反向传播,原理如图 3 所示。




图 3 重参数技巧

首先从标准正态分布中随机采样参量 φ ,再经过参数变换得到服从所需高斯分布的采样变量 Z ,此时对线性变换后的结果进行求取偏导即可完成网络梯度下降训练过程。

解码阶段最终的目标是将原数据样本尽可能还原出来,因此在已有 Z 的基础上需使 $p(X|Z)$ 似然最大化,达到 $\hat{X} \approx X$ 的目的。

本文通过交叉熵损失函数衡量 \hat{X} 与 X 的差异:

$$J = \sum_{i=1}^n -[x_i \cdot \log(\hat{x}_i) + (1 - x_i) \cdot \log(1 - \hat{x}_i)] \quad (8)$$

式(8)中: x_i 与 \hat{x}_i 分别为真实样本与生成样本第 i 个分量。

变分自编码网络总的优化目标函数即为 Encoder 和 Decoder 阶段损失函数的综合:

$$Loss = \min(J + KL) \quad (9)$$

网络经过误差反向传播优化网络参数使目标函数最小化,最终达到数据样本扩展的目标。整体 VAE 网络模型如图 4 所示。

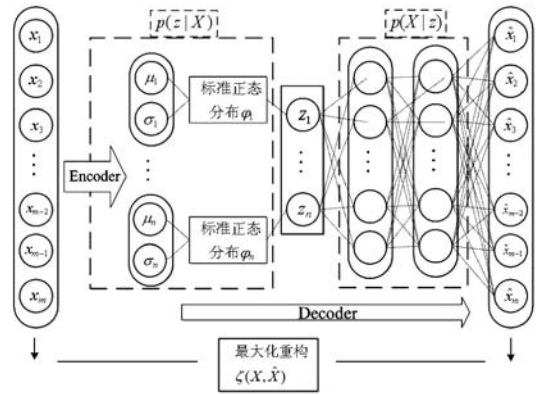


图 4 VAE 数据扩张网络流程

图 4 中,真实故障集 X 的概率分布通过 KL 散度学习分布 $q(Z)$ (近似条件分布 $p(Z|X)$) 编码计算获取输入样本的潜在表达 μ, σ ,并通过重参数技巧(引入标准正态分布)构成潜变量 Z 完成反向传播算法。然后通过交叉熵函数最大化似然条件分布 $p(X|Z)$,使生成样本与真实故障样本相似达到最终故障集构建的目的。

1.2 稀疏自编码网络

本文采用稀疏自编码网络进行电机故障诊断,SAE 与普通自编码器(AE)相似,具有特征提取、数据降维功能,而它们的区别是实现泛化的方式不同。不同于 AE 直接惩罚模型参数实现泛化,SAE 引入稀疏正则项以及稀疏连接提升网络的表征能力,加强训练,并且解决由于深程度泛化引起的过拟合问题^[12]。

如图 5 所示,稀疏自编码网络编码阶段分析多特征数据集提取重要特征,将复杂的数据分布简单拟合,利用 KL 散度引入稀疏正则项惩罚网络激活单元,实现局部连接,权值共享。

$$KL(\rho \parallel \bar{X}(j)) = \rho \cdot \log\left(\frac{\rho}{\bar{X}(j)}\right) + (1 - \rho) \cdot \log\left(\frac{1 - \rho}{1 - \bar{X}(j)}\right) \quad (10)$$

式中: $\bar{X}(j)$ 为隐层第 j 个节点相应的平均值; ρ 为稀疏性参数,接近于 0。




图 5 稀疏自编码

解码阶段将特征进行数据恢复输出预测结果,通过目标函数比较诊断结果与真实结果的可靠性,在不断地迭代中经过随机梯度下降算法按梯度方向修改权值,最终实现最小化目标函数,并记录相应的网络参数。

$$\min_{\theta} J(\theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{X}^{(n)} - x^{(n)}\|_2^2 + \gamma \cdot R(\theta) + \beta \cdot \sum_{j=1}^v KL(\rho \parallel \bar{X}(j)) \quad (11)$$

另一方面隐层引入稀疏连接的关键是为了避免各层神经元提取到重复的特征或额外的噪声特征。此时虽然训练阶段的误差较小但测试结果并不满足要求,这样的现象即为过拟合。Dropout 能够有效解决这种问题,通过伯努利离散分布随机激活或停止输入节点的状态,并以整体概率为 p 作为响应, p 也可以理解为 Dropout 率,其直接影响权值参数的个数。Dropout 作用于 SAE 的编码网络和解码网络能够提升隐层处理效率,增强特征提取以及故障诊断能力。

此时训练好的深度神经网络即可用于永磁同步电机故障诊断。最终深度神经网络诊断流程如图 6 所示。




图 6 深度神经网络诊断流程

2 真实故障数据集的构建

本文利用 MAXWELL 有限元仿真软件构建三相永磁同步电机模型,电机参数设置如表 1 所示。

表 1 三相永磁同步电机参数

参数	值
额定功率/kW	5.5
额定电压/V	220
额定频率/Hz	100
极对数	4
定子槽数	24
并联绕组匝数	148

通过设置电机并联绕组工作匝数模拟匝间短路故障与失磁现象,从而获取 5 000 组特征样本数据集。特征样本部分数据如表 2 所示。

表 2 部分特征样本数据集

$A^{[4]}$	$B^{[4]}$	$C^{[4]}$	$E^{[13]}$	$F^{[13]}$	$T^{[14]}$	标签
0.01	0.04	0.04	0.40	0.28	3.84	1
0.02	0.07	0.05	0.39	0.30	3.97	1
0.45	0.39	0.81	0.36	0.41	4.10	2
0.89	0.27	1.03	0.36	0.44	4.22	2
1.31	0.19	1.34	0.35	0.45	4.32	3
1.97	0.42	1.75	0.29	0.57	4.41	4
2.75	0.7	2.25	0.25	0.67	4.48	4
3.69	1.25	2.83	0.19	0.74	4.53	4

表 2 中: A 、 B 、 C 分别为 A 相、 B 相、 C 相 3 次谐波电流幅值; E 为最低磁密值; F 为磁密波动幅值; T 为电磁转矩。标签值表示电机状态,分配情况见表 3。

表 3 电机状态

标签	状态
1	正常
2	轻微匝间短路
3	严重匝间短路
4	不可逆失磁

本文采用组合特征的方式,将不相关的特征项组成 7 维故障样本集,这样的优势在于:(1) 避免由于某项特征的误差导致诊断错误;(2) 数据集的丰富性以及多样性能够提升深度神经网络学习能力,避免过拟合现象。

3 实验分析

3.1 网络结构优化

在 VAE 数据扩张实验中,将 5 000 组电机故障真实样本以 3:1 的比例建立训练集与测试集,每一批次采样 100 组,连续训练 20 000 次。为寻找最优的网络模型,实验中不断修改网络结构(学习率、学习算法),将测试的准确率作为衡量标准,结果如表 4 所示。

表 4 VAE 参数优化

隐层	学习率	优化算法	准确率/%
3	0.05	Adam	95.8
3	0.01	Adam	98.7
3	0.005	Adam	94.3
3	0.01	SGD	97.3
3	0.01	Adam	98.7
3	0.01	Adagrad	93.1

相同网络条件下,对比不同学习率所对应的准确率可知,学习率的高低对于结果有很大程度的影响,而学习率在 0.01 情况下训练结果最优。同理,选取 Adam(Adaptive Moment Estimation)学习算法作为网络的最优算法。

3.2 样本扩展有效性分析

为展示 VAE 网络样本扩展的有效性,实验将 VAE 编码器数据降维后映射到二维潜在空间上均值的分布可视化,判别隐变量是否具有好的样本重构特性。图 7(a)展示了真实样本潜在分布变化情况,最终将电机样本划分为 4 个区域状态。

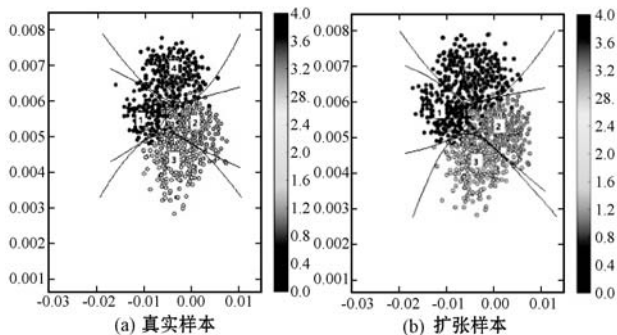


图 7 数据扩展后潜在空间分布

图 7(a)中不同的颜色深度代表不同的状态,很显然训练之后各状态区域均匀分布,彼此之间有明显的界限,则说明潜在空间可以重现输入即存在最小化重构损失(KL 散度)实现潜在分布与先验分布近似。

图 7(b)采样真实故障样本,经过变分自编码

Encoder特征提取,Decoder 合成作用,利用误差函数反向传播学习、优化生成结果,实现伪数据样本的合成。与图 7(a)相比较,显然扩展后的样本潜在空间分布近似于真实数据分布趋势,证实 VAE 生成模型的衍生能力。且扩展后的数据集丰富了原样本,促进样本的多样性,另外由于误差产生的噪声样本,能够增强数据集,提升 SAE 网络故障诊断的鲁棒性。

同时,实验为了实现合成结果的高效性,结合三种误差函数对比分析采取最优方案,结果如表 5 所示。

表 5 VAE 损失函数结果对比

样本数	隐层	算法	准确率/%
5 000	3	交叉熵	99.3
5 000	3	均方误差	93.5
5 000	3	绝对误差	92.7

实验基于相同的电机样本数量,经过 3 层隐层网络(全连接层)迭代 500 次对比不同误差算法最终生成数据的准确性。从表 5 可知,均方误差与绝对误差算法整体的误差偏差差距较小,而交叉熵函数对于处理真伪偏差问题具有较大的优势,误差值明显低于另外两种算法,因此本文采用交叉熵函数作为判别生成模型的准则。

3.3 故障诊断分析

为了展示 SAE 引入 Dropout 稀疏连接对最终结果泛化能力的影响,实验在 SAE 的基础上引入 Dropout 率为 0.5 的稀疏连接,以相同的真实样本为数据源,分别将正常 SAE 以及处理后的 SAE 作为诊断模型,实验结果如表 6 所示。

表 6 处理前后 SAE 泛化能力比较

样本	诊断网络	准确率/%
5 000	SAE	97.3
5 000	SAE + Dropout	98.5

显然稀疏连接的引入能够更好地发挥深度网络的表征能力以及强泛化能力。因此本文 SAE 诊断模型即为处理后的 SAE 网络。

为了进一步展示特征分析的合理性以及数据扩展的高效性,实验将真实样本以及扩展样本分别作为训练网络输入,稀疏化节点提取样本重要特征并进行反复学习,将训练完成的网络用作判断故障诊断的标准,并用测试数据检验诊断效率。实验基于相同 SAE 网络对比不同数据集下的故障诊断结果如图 8 所示。




图8 不同训练集条件下诊断偏差对比

两组实验分别经过相同参数(隐藏层:3;隐层节点:10;批处理量:100;步数20 000)的SAE网络,比较不同特征样本集故障诊断的优劣程度。

(1) 实验1将合成的5 000组本文特征分析故障数据集(A,B,C,E,F,T)作为网络输入,显然样本的数量直接影响诊断效率的高低,且随着样本数量的升高准确率趋于缓和,达到最优结果,最终诊断效率达到96.6%。

(2) 在实验2的基础上增加本文提出的VAE数据扩张,增加2 500组额外样本集。由于扩张的数据是从无到有的过程,生成的伪数据通常会携带非相关噪声元素,而这样的样本作为训练数据反而能够提高网络的泛化能力,防止过拟合现象。因此从图8中可以看出,5 000组相同样本数下扩展后特征集准确率会略微高于组合特征集情况。另外样本数过少网络训练无法达到最终状态且诊断效率无法处于最优目标,从额外的样本集诊断结果能够观察到,随着样本数的增多准确率也渐渐趋向于稳定达到99.3%,证明VAE扩展组合特征对于永磁同步电机匝间短路及永磁体失磁故障诊断的高效性。

3.4 与传统方法的对比

不同诊断方法对比结果如表7所示。

表7 不同诊断方法结果对比分析

样本	数据集	方法	准确率/%
5 000	真实样本	WT + SVM ^[1]	85.6
5 000	真实样本	EMD + SVM ^[3]	88.3
5 000	真实样本	BP ^[5]	88.7
5 000	真实样本	模糊 + BP ^[5]	90.0
5 000	真实样本	DSAE ^[7]	98.6
7 500	扩张样本	本文方法	99.3

(1) 小波变换以及经验模态分解作为传统信号处理方法,与SVM分类器相结合用作电机故障诊断。诊断结果展示了这两种方法的实用性,且相对神经网络其结构简单,计算方便,但效率不及另外几种方法。

(2) BP神经网络作为回归、分类问题的常客,其良好的监督学习以及泛化能力在电机故障诊断领域也有较好的深入,且结果也比较让人满意。从表7中看出,BP诊断效率为88.7%足以证明BP的可行性,但整体效率还需大幅提升。

(3) 模糊逻辑与BP神经网络的结合,既继承了知识的模糊性,又兼顾了网络学习能力强的特点,其核心是利用阈值向量判别方法。这样的诊断策略从最终的诊断效率可以看出它的可靠性以及灵活性。

(4) 最后两种方法的共同点在于它们都是基于深度学习网络来实现电机故障诊断。DSAE是在稀疏自编码网络的基础上增加噪声的方法来提高训练的鲁棒性,其诊断效率达到98.6%,证实深度学习在故障诊断的高效性。而本文提出VAE + SAE的方法,通过深度学习数据扩张模型一方面增加样本数量提升数据集多样性,另一方面由于误差产生的噪声数据可以达到增强数据集的作用,其优势在于减少人工工作量,减少计算机资源消耗,并能够获得精确的诊断结果。

4 结 语

组合特征融合深度学习变分自编码网络可以有效分析永磁同步电机匝间短路及失磁故障,弥补深度网络大数据背景下样本不足等问题。本文主要结论如下:

(1) 频域电流、磁通密度、电磁转矩特征分析可以结合相关因素,减少由于数据采集失误引起的巨大偏差。相比于单一特征项数据,本文组合特征细化故障元素,从不同角度综合分析故障优劣程度,展示其对于匝间短路和失磁故障的合理性。

(2) 引入变分自编码网络高效扩展特征,一方面增加数据集数量,另一方面增强了数据集。与人工采集数据集相比,优势在于:节约时间、减少成本。另外生成的伪数据能够提高训练网络的抗干扰能力,从而实现高效故障诊断。

(3) 故障诊断模型引入稀疏性原理提升了自编码网络的泛化能力,避免过拟合现象,并优化了整体的故障诊断效率。

参 考 文 献

[1] 杨存祥,牛云龙,张志艳,等.小波包分析在永磁同步电

- 机转子偏心故障中的应用[J]. 电机与控制应用, 2015(4):42-46.
- [2] 蒯松岩, 赵帅, 张中, 等. 基于有限元分析的开关磁阻电机电感模型无位置传感器技术[J]. 电机与控制应用, 2017, 44(2):70-77.
- [3] 张彦霞, 肖清泰, 徐建新, 等. 基于经验模态分解的小波神经网络预测模型[J]. 计算机应用与软件, 2016, 33(10):284-287.
- [4] 阳同光, 蒋新华, 付强. 瞬时功率频谱分析在牵引电机转子故障诊断的应用研究[J]. 电机与控制学报, 2012, 16(10):95-99.
- [5] 李宏, 王崇武, 贺显曜. 基于参数估计模型的对转永磁无刷直流电机实时故障诊断方法[J]. 西北工业大学学报, 2011, 29(5):732-737.
- [6] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. 中国机械工程, 2017, 28(9):1056-1061.
- [7] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9):65-71.
- [8] Goyal P, Hu Z, Liang X, et al. Nonparametric Variational Auto-Encoders for Hierarchical Representation Learning [C]//IEEE International Conference on Computer Vision. IEEE Computer Society, 2017:5104-5112.
- [9] Qi Z F, Liu Q Q, Wang J, et al. Battle damage assessment based on an improved Kullback-Leibler divergence sparse autoencoder[J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(12):1991-2000.
- [10] 梁中军, 邹华, 郭静, 等. 基于多维特征挖掘的服务质量预测方法[J]. 电子学报, 2014.
- [11] Kingma D P, Salimans T, Welling M. Variational dropout and the local reparameterization trick [EB]. eprint arXiv: 1506.02557, 2015.
- [12] 李垣江, 张周磊, 李梦含, 等. 采用深度学习的永磁同步电机匝间短路故障诊断方法[J/OL]. 电机与控制学报:1-8[2018-12-17]. <http://kns.cnki.net/kcms/detail/23.1408.TM.20181018.1422.004.html>.
- [13] 伍召莉. 永磁同步电机失磁分析及在线监测[D]. 北京: 北京交通大学, 2012.
- [14] Guo H, Xu J. Fault tolerant control with torque limitation based on fault mode for ten-phase permanent magnet synchronous motor[J]. Chinese Journal of Aeronautics, 2015, 28(5):1464-1475.
- [15] 张振红, 焦留成, 王大虎, 等. 基于模糊神经网络的故障诊断在永磁直线同步电动机中的应用[J]. 电机与控制学报, 2003(1):22-25.
- Systems, 2017, 120(1):99-117.
- [7] Feng X, Hu X, Liu Y. Radar signal sorting algorithm of k-means clustering based on data field [C]//2017 3rd IEEE International Conference on Computer and Communications (ICCC). IEEE, 2017: 2262-2266.
- [8] Jiang J, Hao D, Chen Y, et al. GDPC: Gravitation-based Density Peaks Clustering algorithm [J]. Physica A: Statistical Mechanics and its Applications, 2018, 502(1): 345-355.
- [9] Geng Y, Li Q, Zheng R, et al. RECOME: a new density-based clustering algorithm using relative KNN kernel density [J]. Information Sciences, 2018, 436(1): 13-30.
- [10] Liu R, Wang H, Yu X. Shared-nearest-neighbor-based clustering by fast search and find of density peaks [J]. Information Sciences, 2018, 450(1): 200-226.
- [11] 李涛, 葛洪伟, 苏树智. 自动确定聚类中心的密度峰聚类 [J]. 计算机科学与探索, 2016, 10(11):1614-1622.

~~~~~

(上接第 106 页)

- [9] Zhao D W, Tan J J, Yang W B, et al. An improved vibe algorithm for fast suppression of ghosts and static objects [C]//IEEE International Conference on Mechatronics and Automation (ICMA). Changchun, China, 2018:889-893.
- [10] Van Droogenbroeck M, Paquot O. Background subtraction; Experiments and improvements for vibe [C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshop. Providence, RI, IEEE, 2012:32-37.
- [11] 于之靖, 马凯, 王志军, 等. 采用改进 KLT 算法的标志点匹配方法 [J]. 激光与光电子学进展, 2018, 55(2):108-114.
- [12] Xu Y M, Zhang J, Gu J P, et al. An optimized Vibe target detection algorithm based on gray distribution and Minkowski distance [C]//32nd Younth Academic Annual Conference of Chinese Association of Automation (YAC). Hefei, China, 2017:66-71.
- [13] 薛阳, 张亚飞, 杨天宇, 等. 一种针对抖动视频序列的运动目标检测算法 [J]. 激光与光电子学进展, 2018, 55(9): 332-338.
- [14] Goyette N, Jodoin P, Porikli F et al. Changedetection.net: A new change detection benchmark dataset [C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshop. Providence, RI, IEEE, 2012:1-8.
- [15] Zivkovic Z. Improved adaptive gaussian mixture model for background subtraction [C]//Proceedings of the 17th International Conference on Pattern Recognition. Cambridge. IEEE Computer Society, 2004:28-31.
- [16] Sajid H, Cheung S C. Universal multimode background subtraction [J]. IEEE Transactions on Image Processing, 2017, 26(7):3249-3260.

~~~~~

(上接第 70 页)

- [6] Xu J, Wang G, Li T, et al. Fat node leading tree for data stream clustering with density peaks [J]. Knowledge-Based